

加速度センサーメトリクスとその応用に関する研究 Studies on Accelerometer Metrics and the Applications

小林 孝史[†] 平松 耕輔[‡]
Takashi Kobayashi Kosuke Hiramatsu

1. はじめに

我々は、これまでに、加速度センサーや角速度センサーを用いた個人認証アプリケーションについての研究を行ってきた[1]。人が作り出すモーションは数多くのバリエーションがあり、それぞれを個人識別に利用することが可能である。以前の研究においては、簡単なモーションのみならず、複雑なモーションを利用した個人識別が可能であることがわかっている。

また、近年では、同様のセンサーを利用した研究分野が急速に広がりを見せており、情報科学のみならず、スポーツ科学[2]、動物学[3]、行動解析[4]等に应用されている。

モバイル機器に搭載されている加速度センサーからのデータは同一のものではなく、かなりばらつきがあることがわかっている。例えば、加速度センサーから時系列データを取得すると、その周波数成分の特徴は加速度センサーごとにかなり異なるものになる。その理由としては、加速度センサー本体の製造上の差異であったり、センサーを取り巻く回路構成要素に誤差が生じていたりすることが原因である。本研究では、加速度センサーからデータを取得する回路を構成し、それらから得られるデータを集めて各センサー個体の識別を試みる。

2. 静止状態での加速度センサーからの情報

これまでの研究により、加速度センサーから得られたデータはさまざまに変化することが分かっている。その理由は、加速度センサー自体の製造工程に起因する誤差や、それを取り巻く回路構成要素の誤差による。図 1 に二つの種類の携帯デバイスから得られた加速度センサーの時系列情報を周波数解析した結果を示す。この時系列データは、二種類の携帯デバイスを安定した台の上に水平に静止させた状態で測定して得られたもので、静止しているにも関わらず、さまざまな周波数成分が含まれていることが分かる。機種が異なることもあるが、静止した状態でこのような周波数特性を有するため、この特徴を利用した個体識別の可能性を含んでいると考えている。

3. 加速度センサーの仕組みと精度

モバイルデバイスに搭載されている加速度センサーは MEMS (Micro Electro Mechanical System) によって構成されており、半導体ウェハの上に機械的構造と集積回路の構造の両方を有した構造となっている。そのため、一つのセンサーが機械的な精度と集積回路の精度の二つの精度の組み合わせを持つことになる。本研究ではその精度に注目したことになる。製造プロセスにおける精度の違いが出てくることが知られており、加速度センサーのスペックシートにも記述されている。例えば、1000 個体以上のセンサー

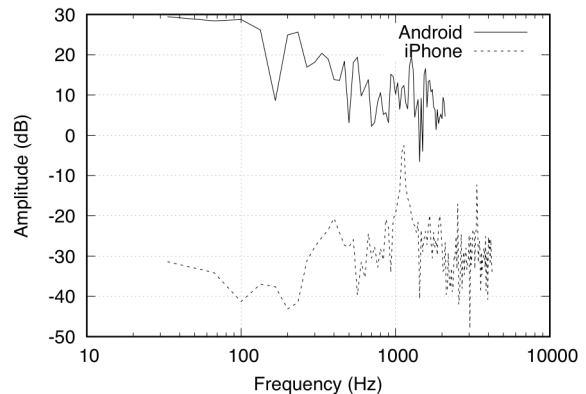


図 1 加速度センサーから得られたデータの周波数特性

から得られた電圧分布と温度特性が示されている。

加速度センサーから更にデータを取得するためには、少なくとも電気、電子回路を構成する必要がある。それらの構成要素の精度はかなり異なるため、センサーを組み込んだ回路の構成には違いが生じることとなり、そのような誤差は回避できないものである。これらのセンサー（および周辺回路）に存在する精度の違いに着目し、センサーからの出力値に基づいた個々のセンサーの違いを発見し、個体識別に適用することを試みる。

4. 加速度センサーからのデータ取得

加速度データは加速度センサーを搭載したデバイスからプログラムを用いて取得する方法と、加速度センサーから直接取得する方法の二種類がある。加速度センサーを搭載したデバイスからのデータ取得は多くのデバイスを用意する必要があり、現在の研究では、加速度センサー自体から直接取得する方法を採用した。

本研究では、アナログデバイス社の ADXL327BCPZ[5]を用いており、X、Y、Z 軸の出力端子に $0.1\mu\text{F}$ のキャパシタを取り付けたものを用意した。入力電圧は $1.8\sim 3.6\text{V}$ である。

評価回路からセンサーの各軸の情報を取得するため、Raspberry Pi3 を用いている (図 2)。Raspberry Pi は GPIO (汎用入出力ポート) を備えた、極小コンピュータの一種である。Raspberry Pi は GPIO ポートを通じて加速度センサーに電源供給を行うことができ、Raspberry Pi からの供給できる電圧 3.3V は加速度センサーへの入力電圧の範囲内にある。加速度センサーからはアナログ値が出力されるが、Raspberry Pi はアナログ値をそのまま取り込むことができないので、センサーデータの測定は 12 ビット AD コンバータである MCP3208 を介して行なった。出力される値の

[†] 関西大学 総合情報学部

[‡] 関西大学大学院 総合情報学研究科知識情報学専攻

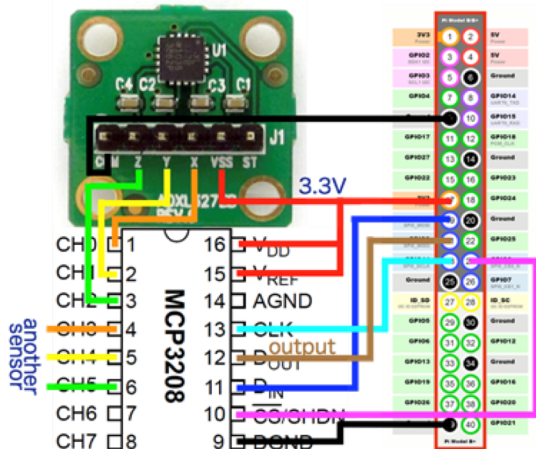


図 2 加速度センサーの測定環境




図 3 取得した各センサーの情報

例として、0 は 0V を、4095 は印加電圧である Vss を意味する。

本研究では 8 つの加速度センサーを準備し、同一の設置条件・環境条件下に置いた。センサーを搭載した評価回路の設置については、安定した台の上に回転等が加わらないように安定した状態に維持するため、8 個の評価回路を厚手のアクリル板に固定した。測定環境は安定した台の上に用意し、実験は振動などが加わらない環境下で行なった。

5. 加速度センサーの識別手法

まず、8 つの加速度センサーから収集したデータを元に、識別用のデータセットを作成した。取得した各センサーのデータの一部を図 3 に示す。この図からも明らかなように、それぞれのセンサーから出力される値はかなり異なるものとなっている。本研究では、このようなセンサーからの時系列情報を分類し、それぞれのセンサー個体を識別することを試みる。

5.1 センサーから入手するデータの次元数削減

各センサーからは、X 軸、Y 軸および Z 軸の 3 つの情報取得できる。それをそのまま使ってもよいが、次元数 3 のデータの系列を用いて識別することになるので、まずは




図 4 ニューラルネットワークの構成

この次元数を削減することを考える。次元数を下げる方法としては(1)式を採用した。

$$\text{value} = \sqrt{x^2 + y^2 + z^2} \quad (1)$$

x, y および z はそれぞれ、X 軸、Y 軸および Z 軸のセンサーデータを表している。それぞれを二乗したものを加算し、その平方根を取ったもので、加速度ベクトルの大きさを求めていることになる。この方法では、動きの少ない軸のデータが活用されないことになるが、本研究の場合は、静止状態でのセンサーデータを取得しているため、取得するデータの変動は元々微小であることを想定しており、時系列としては問題ない。逆に、モーション全体を識別するような場合には、動き、つまり変動の少ない軸の情報が抜け落ちて、識別結果が変動の大きな軸のデータに依存してしまう結果となることが分かっている[1]。

5.2 識別に用いるデータセットと入出力関係の同定

式(1)の方法で次元数を削減したデータを各センサーから取得し、128 個ずつの時系列データとして、それを 100 セットずつ用意した。8 つのセンサーについて合計 800 セットの入力データセットとなり、そのうちの 1 セット分 128 個の入力データが与えられたときに、8 つのセンサーのいずれかに該当するか、という識別問題となる。i 番目のデータセットを \mathbf{D}_i 、それが属するセンサー番号を \mathbf{S}_i とすると、その間の関係は式(2)のように表すことができる。

$$\mathbf{D}_i \mathbf{T} = \mathbf{S}_i \quad (2)$$

ここで、 \mathbf{T} はセンサーからのデータ系列からセンサー番号へ変換する系である。すべての \mathbf{D} から \mathbf{S} への変換を行なうためには、データセット数 800 セットすべてに対して適切なセンサー番号を提示できるように系 \mathbf{T} を構成する必要がある。 \mathbf{D} は 1 セットあたり 128 個のデータで構成されており、それが 800 セット存在するため、行列で表すならば 128 列 800 行の行列となる。 \mathbf{S} も同様に、1 (8 つのセンサーがそれぞれある数値で表現される場合) または 8 (8 つのセンサーがそれぞれベクトルで表現される場合) の情報が 800 セット存在することから、1 列 800 行または 8 列 800 行の行列となる。 \mathbf{D} の逆行列を \mathbf{S} に右からかけることによって系 \mathbf{T} を求めることは可能である。このとき、 \mathbf{D} は当然ながら正方行列ではないから、 \mathbf{D} の擬似逆行列によって \mathbf{T} を求めることができる。このときの \mathbf{T} は、 \mathbf{D} と \mathbf{T} の

表 1 試行回数ごとのテストデータの正解率

試行回数	センサー番号		
	1	5	8
1	0.971	1.000	1.000
2	1.000	1.000	0.951
14	0.931	1.000	1.000
15	0.970	1.000	1.000
20	1.000	0.029	1.000

表 2 データセットを変更後の試行回数ごとのテストデータの正解率

試行回数	センサー番号		
	1	5	8
4	0.970	1.000	1.000
6	0.970	1.000	1.000
8	0.960	1.000	1.000
15	0.967	1.000	1.000
16	0.972	1.000	1.000
17	0.968	1.000	1.000
20	0.968	1.000	1.000

行列演算の結果出てくる 800 セットのセンサー番号と正しいセンサー番号データ S の間の誤差が最も小さくなるように求められているから、この D と S の入出力関係を最適化した結果と見ることができると考えられる。

5.3 ニューラルネットワークによる系の同定

このように、この系 T を代数的な解として求めることも可能であるが、汎用性の面を考慮して、ニューラルネットワークを用いた系の同定を行う。入力層 128 ユニット、出力層は 8 ユニットという構成にしている。中間層は 5 層で、それぞれ 100 から 20 ユニットと、段階的にユニット数を減らしている (図 4)。出力層の活性化関数は出力層への入力をそのまま出力するようにしてあり、その他の中間層の活性化関数は ReLU 関数、いわゆるランプ関数を用いている。入力値が正の場合にのみ入力値を返す関数で、入力が負の場合にはゼロを返す。不連続点を持つのがこれが最良といわれているため、この関数を採用している。

ニューラルネットワークの学習方法としては、バッチ型の学習方法を採用し、一定のパターン数ごとに出力誤差を蓄積し、まとめて学習を行なった。800 パターンのうち、30%に相当する 240 パターンをテストデータとし、残りの 560 パターンでニューラルネットワークの学習を行なった。この試行では明確な交差検定を行っていない。その理由は、240 パターンをテストデータとして分離するが、毎回各センサーのデータセットからランダムに選択され、各センサーから平均 30 パターンずつ選ばれるようになってい




図 5 センサー1と8の時系列の比較

るからである。平均 30 パターンであるので、20 パターンほどに少なくなることや 40 パターン近く選ばれることもある、というテストデータの構成になるため、完全に交差検定を行っていないのではなく、試行全体を通したテストデータの構成が交差検定に近くなっていると考えている。

5.4 系の同定と識別実験

前節で説明したデータセットおよびニューラルネットワークを用いて、系の同定とセンサー個体の識別実験を行った。学習試行 1 回当たり最大 40000 回の学習を行い、同時にテストデータによる識別試行を行なった。この試行を 20 回繰り返した結果の一部を表 1 に示す。表 1 に掲載されていない試行回数の行およびセンサー番号の列はすべて 1.000、つまりすべて正解であった。ちなみに、学習データについては、いずれの試行においてもすべて正解であった。

この結果から、ほとんどの試行においてセンサー番号を正しく識別できていることが分かる。表 1 に載せたものはそれぞれの試行において、不正解となったセンサー番号のみである。試行回数 20 回目のセンサー番号 5 の正解率が非常に低い (35 パターンのうち正解が 1 パターンのみ) 以外は、1 パターンだけが不正解となっている。センサー 5 の正解率の低さは、この試行のみのものであり、さらに 20 回試行を繰り返したが、その場合はセンサー 5 については不正解となったパターンは一つもなく、すべて正解となった。センサー 1 と 8 については、表 1 と同様にいくつかの試行において、1 パターンずつ不正解が発生するという状況であった。

複数の試行において、センサー 1 と 8 に不正解が生じるのは、図 3 に示した時系列データからも説明できると考えている。つまり、センサー 1 と 8 の時系列が非常に似ている、ということである。念のため、図 5 にこれらのセンサーから得られた時系列データの比較図を掲載した。図 5 から明らかなように、これら二つのセンサーから得られた時系列は、他のセンサーと比較して、非常に似かよったものとなっているため、識別時にはお互いのセンサーであると判定したことになると思われる。

5.5 使用する測定データによる識別性能の検証

これらの試行に利用したデータセットは、加速度センサーからのデータを測定し始めた部分のデータで構成されている。測定を始めた部分というのは、測定環境が安定していないことも考えられる。そこで、十分な時間が経過した部分からデータを抽出した場合のデータセットでの学習・識別実験を実施し、識別性能に差異が発生するかどうかの検証を行なった。データセットの測定は各センサーで 12000 点行っており、表 1 の結果を得た試行に用いたのは各センサーの最初の 128 データ×100 セット分である。12000 点のデータを取得するのに約 10 分の時間がかかっているため、各データの最後の 100 セット分を抽出したものをを用いて追加の学習・識別実験を行なった。その結果の一部を表 2 に示す。

この試行においても、センサー1 については不正解が出やすいことが分かる。不正解となったのも、それぞれ 1 パターンずつとなっている。表 2 に示した以外に他の 20 回の試行を追加実施したが、その場合にもセンサー1 については 3 試行で不正解が 1 パターンずつ、センサー8 について 1 試行の 1 パターンで発生しており、このことからセンサー1 および 8 については不正解が出やすいセンサーであることがわかった。センサー5 については不正解となったパターンは存在しなかった。センサー1 および 8 の不正解の状況については詳細の解析ができていないので、今後、追加で実施することとしたい。

6. おわりに

本研究では、加速度センサーからのデータを取得するための回路作成を行い、同条件で複数のセンサーからのデータを取得した。そのデータセットの中から抽出したデータを用いて学習・識別実験を行い、測定開始直後のデータおよび測定終了間際のデータのどちらの場合においても高い精度でセンサー個体の識別ができることを示した。一部のセンサーで、テストデータでの不正解があり、お互いのセンサーと混同してしまっている可能性を指摘した。識別結果の詳細の解析については今後の課題としたい。

本研究で用いた 8 つの加速度センサーについてはこのように識別することができているが、これは取得したデータセットに関してのみ可能になっていることである。別の加速度センサーからのデータを入力した場合は、学習した 8 つのセンサーのいずれか近いセンサーとして識別されることになる。本研究で行なった実験では、センサー固有の情報を抽出したわけではないので、今後は固有情報の抽出について中心に研究を進めていく予定である。

謝辞

本研究の一部は、平成 27～28 年度関西大学研究拠点形成支援経費による研究経費の助成を受けて行われたものである。

参考文献

- [1] 高坂, 平松, 小林, "スマートフォンのモーションセンサーを利用した個人認証アプリケーションの開発," 第 15 回情報科学技術フォーラム 2016 講演論文集, L-020, 2016.
- [2] Sarah Kozey Keadle, Joshua N Sampson, Haocheng Li, Kate Lyden, Charles E Matthews, Raymond J Carroll, An Evaluation of Accelerometer-derived Metrics to Assess the Daily Behavioral Patterns, *Medicine and Science in Sports and Exercise*, 49(1), pp.54--63, 2017.

- [3] Fehlmann, Gaelle, et al. "Identification of behaviours from accelerometer data in a wild social primate." *Animal Biotelemetry* 5.1 (2017): 6.
- [4] Lee, Song-Mi, Sang Min Yoon, and Heeryon Cho. "Human activity recognition from accelerometer data using Convolutional Neural Network." *Big Data and Smart Computing (BigComp)*, 2017 IEEE International Conference on. IEEE, 2017.
- [5] ADXL327CPZ Datasheet, Analog Devices Inc., <http://www.analog.com/media/en/technical-documentation/datasheets/ADXL327.pdf> (retrieved: Jun. 29th, 2017).